

KLASIFIKASI KENYENYAKAN TIDUR BERDASARKAN UMUR PADA SINYAL *ELECTROENCEPHALOGRAPH* DENGAN MELIHAT KONDISI *NON RAPID EYE MOVEMENT*

CLASSIFICATION DEPTH OF SLEEP BASED ON AGE BY USING ELECTROENCEPHALOGRAPH WAVE WITH SEE NON RAPID EYE MOVEMENT

Naufal Rizky Pratama¹, Raditiana Patmasari², Sugondo Hadiyoso³

¹Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

²Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

³Prodi D3 Teknik Telekomunikasi, Fakultas Ilmu Terapan, Universitas Telkom

¹naufalrizky@telkomuniversity.ac.id, ²raditiana@telkomuniversity.ac.id, ³
sugondo@tass.telkomuniversity.ac.id

Abstrak

Manusia membutuhkan tidur untuk mengekang *stress* di dalam diri. Kurang tidur membuat mudah *stress*, cemas, dan juga tegang. Maka dari itu tidur yang cukup sangatlah penting. Saat tidur, otak beraktivitas, merespon, dan menghasilkan *brainwave* atau sinyal otak. Dalam tidur terbagi dua metode kondisi mata yaitu *Rapid Eye Movement* (REM) dan *Non Rapid Eye Movement* (NREM). Salah satu cara untuk mendeteksi dan merekam sinyal otak yang disebabkan oleh aktivitas neuron pada otak manusia adalah *Electroencephalography* (EEG). Oleh karena itu penelitian ini mengklasifikasikan kondisi kenyamanan tidur pada sinyal EEG yang di ekstraksi ciri dengan HJORTH Descriptor. Setelah itu akan diklasifikasikan menggunakan *Support Vector Machine*.

Dalam mengklasifikasikannya penelitian ini mengambil data dari penelitian *Analysis of a Sleep-Dependent Neuronal Feedback Loop: The Slow-Wave Microcontinuity of the EEG*. Data ini sudah melalui tahap proses *pre-processing* data yang ada di *database*, setelah itu menggunakan metode *Hjorth Descriptor* untuk mengekstraksi ciri fitur sinyal EEG dan diklasifikasi menggunakan SVM untuk melihat kondisi tidur tersebut termasuk dalam kategori nyenyak, kurang nyenyak, atau bahkan tidak nyenyak.

Dalam penelitian ini hanya mengambil 39 data yang terdiri dari 20 *correspondent* dan dalam 2 kondisi malam yang berbeda. Malam pertama perekaman tidur normal. Malam kedua perekaman tidur dengan diberikan obat tidur kepada *correspondent*. Penelitian ini memperoleh parameter keberhasilan 100% menggunakan kernel *Linear SVM*, menghasilkan keluaran kondisi tidur yang terdiri dari tidur nyenyak pada saat lampu dimatikan, tidur kurang nyenyak pada saat mau terbangun, dan tidur tidak nyenyak pada saat awal tidur.

Kata kunci : EEG, NREM, REM, HJROTH Descriptor, SVM

Abstract

Human need sleep to curb stress. Lack of sleep make easy stress, worried, and uptight. Therefore enough sleep is more important. At sleep, the brain moves, respond, and generate brainwave. In sleep has divided two condition method eye there is Rapid Eye Movement (REM) and Non Rapid Eye Movement (NREM). Either way to detect and record brainwave is Electroencephalography (EEG). Therefore this research will classify depth of sleep in EEG signal using HJORTH Descriptor to extraction the feature of data. After that will classify using Support Vector Machine.

In classifying it, this research take data from research Analysis of a Sleep-Dependent Neuronal Feedback Loop: The Slow-Wave Microcontinuity of the EEG. The data has been pre-processing, after that using HJORTH Descriptor to extract characterstic feature signal of EEG and classify using SVM too see the sleep condition included in the category depth of sleep, well sleep, or not well sleep.

In this research just took 39 data consisting of 20 correspondent in two night difference condition. The first night normal sleep recorded. The second night Temazepam has given to correspondent. This research has been reach 100% using Linier kernel SVM, produce output condition of sleep consisting of depth of sleep when the lights off, well sleep when before waking up, not well sleep when the lights on.

Keywords: EEG, NREM, REM, HJROTH Descriptor, SVM

1. Pendahuluan

Pengukuran aktivitas otak dengan EEG memberikan banyak keuntungan untuk berbagai aplikasi khususnya yang membutuhkan inputan dari manusia. Sebagai contoh, rangsangan otak dapat digunakan sebagai inputan untuk permainan komputer, untuk melacak emosi seseorang, digunakan difabel untuk mengendalikan peralatan, dan untuk keperluan militer. Untuk dua contoh terakhir membutuhkan deteksi rangsangan otak yang akurat untuk menghindari kesalahan. Oleh karena itu penting untuk menentukan rangsangan tertentu yang bisa dideteksi dengan akurasi yang memadai[1].

Penelitian tentang tidur sudah banyak, ada yang meneliti tentang pengaruh obat tidur[2], pengaruh umur[2][3], bahkan pengaruh jenis kelamin[4]. Penelitian tersebut mendapatkan hasil bahwa kenyamanan tidur seseorang itu dipengaruhi umur dan juga obat tidur[2]. NREM adalah gelombang tidur yang lambat yang mana pada gelombang EEG menggunakan gelombang delta[2]. Penelitian tentang tidur menggunakan metode *HJORTH Descriptor* sudah dilakukan, ada yang meneliti tentang stabilitas dan kualitas tidur dan juga ada yang meneliti tentang kompleksitas sinyal EEG saat tidur pada *HJORTH Descriptor*. Perbedaan dengan penelitian ini, penulis menggunakan dataset yang berbeda dan juga parameter yang berbeda karena penelitian ini mengklasifikasikan kondisi kenyamanan tidur.

Dalam tidur nyenyak harus ada kondisi NREM dan REM yang memenuhi[2],[3]. *Hjorth Descriptor* sering digunakan untuk menganalisis sinyal EEG dalam domain waktu [5] Maka dari itu penulis akan mengklasifikasikan kondisi kenyamanan tidur pada saat lampu mati dibandingkan dengan awalnya tidur tanpa mematikan lampu dan juga sejam sebelum terbangun. Setelah mengklasifikasikan akan terlihat apakah kondisi delta saat lampu dimatikan mempengaruhi kenyamanan tidur seorang dan penulis menggunakan *Hjorth Descriptor* untuk mengekstraksi ciri datanya. Setelah itu data akan diklasifikasikan menggunakan *Support Vector Machine*.

2. Dasar Teori /Material dan Metodologi/perancangan

2.1 *Electroencephalography*

Electroencephalography merupakan metode untuk merekam aktivitas elektrik pada otak manusia di sepanjang kulit kepala. EEG mengukur fluktuasi tegangan yang dihasilkan oleh arus ion didalam neuron otak. Dalam konteks klinis EEG mengacu kepada perekaman aktivitas elektrik spontan dari otak selama periode tertentu yang direkam dari elektroda yang dipasang di kulit kepala dan alat perekamnya disebut electroencephalogram. Hasil dari EEG sendiri berupa grafik yang memuat banyak informasi tentang aktivitas otak. Neuron akan menghasilkan gelombang elektrik ketika mereka aktif. Sinyal yang direkam berupa sinyal analog yang telah dikonversi menjadi sinyal digital yang terbagi menjadi 5 band frekuensi dengan 5 bentuk sinyal yang berbeda, yaitu alfa, betha, theta, delta, dan gamma. Sinyal EEG direkam untuk kepentingan analisis lebih lanjut[8].

2.2 *EDF Database*

Data yang digunakan sebagai masukan dalam penelitian klasifikasi kenyamanan tidur ini merupakan data sekunder yang di dapatkan dari *The Sleep-EDF Database*, Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: *Components of a New Research Resource for Complex Physiologic Signals*[2] [5]. *EDF Database* merupakan situs untuk mengunggah dan mengunduh data dari suatu penelitian yang terfokus pada analisis tentang tidur maupun sinyal-sinyal *electroencephalograph* lainnya.

EDF Database untuk klasifikasi kenyamanan tidur yang digunakan pada penelitian ini mengambil 39 *sample* data yang terdiri dari dua kondisi, yaitu malam pertama kondisi biasa tanpa dikasih obat tidur. Malam kedua kondisi

tidur yang diberikan obat tidur. Rentang umur yang diambil dalam penelitian ini adalah 20-40 tahun. Tiap partisipan mengalami kondisi susah tidur sebelumnya dan akan dilihat bagaimana sinyal antara tidur biasa dengan diberikannya obat. Penelitian ini akan melihat tiga parameter sinyal yaitu sinyal delta saat pertama direkam (lampu masih menyala), sinyal delta 60 menit saat lampu mati, dan sinyal delta saat mau bangun tidur.

2.3 HJORTH Descriptor

HJORTH Descriptor adalah metode ekstraksi ciri data untuk menganalisis sinyal EEG dalam domain waktu[5]. Metode *HJORTH Descriptor* memiliki tiga parameter yakni[5]:

a. Parameter Aktifitas

Parameter aktifitas merepresentasikan daya sinyal dan variansi dalam fungsi waktu. Persamaan parameter aktifitas yakni sebagai berikut :

$$\text{Aktifitas} = \text{var}(y(t)) \quad (2.1)$$

Keterangan :

$y(t)$ = data input pada sumbu y.

var = variansi.

Dari persamaan rumus 2.1. Rumus variansi sama dengan standar deviasi kuadrat. Rumus standar deviasi adalah sebagai berikut :

$$\text{Standar Deviasi}(y(t)) = \sqrt{\frac{\sum_{i=0}^t (y_i - \bar{Y})^2}{t-1}} \quad (2.2)$$

Keterangan :

\bar{Y} = Rata-rata jumlah data input

t = Banyaknya data

Setelah mendapatkan rumus standar deviasi. Maka bisa didapatkan rumus variansi antara lain sebagai berikut :

$$\text{Variansi}(y(t)) = \frac{\sum_{i=0}^t (y_i - \bar{Y})^2}{t-1} \quad (2.3)$$

b. Parameter Mobilitas

Parameter mobilitas merepresentasikan frekuensi rata-rata atau proporsi dari standar deviasi spektrum daya. Persamaan parameter mobilitas sebagai berikut :

$$\text{Mobilitas} = \sqrt{\frac{\text{var}(dy(t))}{\text{var}(y(t))}} \quad (2.2)$$

c. Parameter Kompleksitas

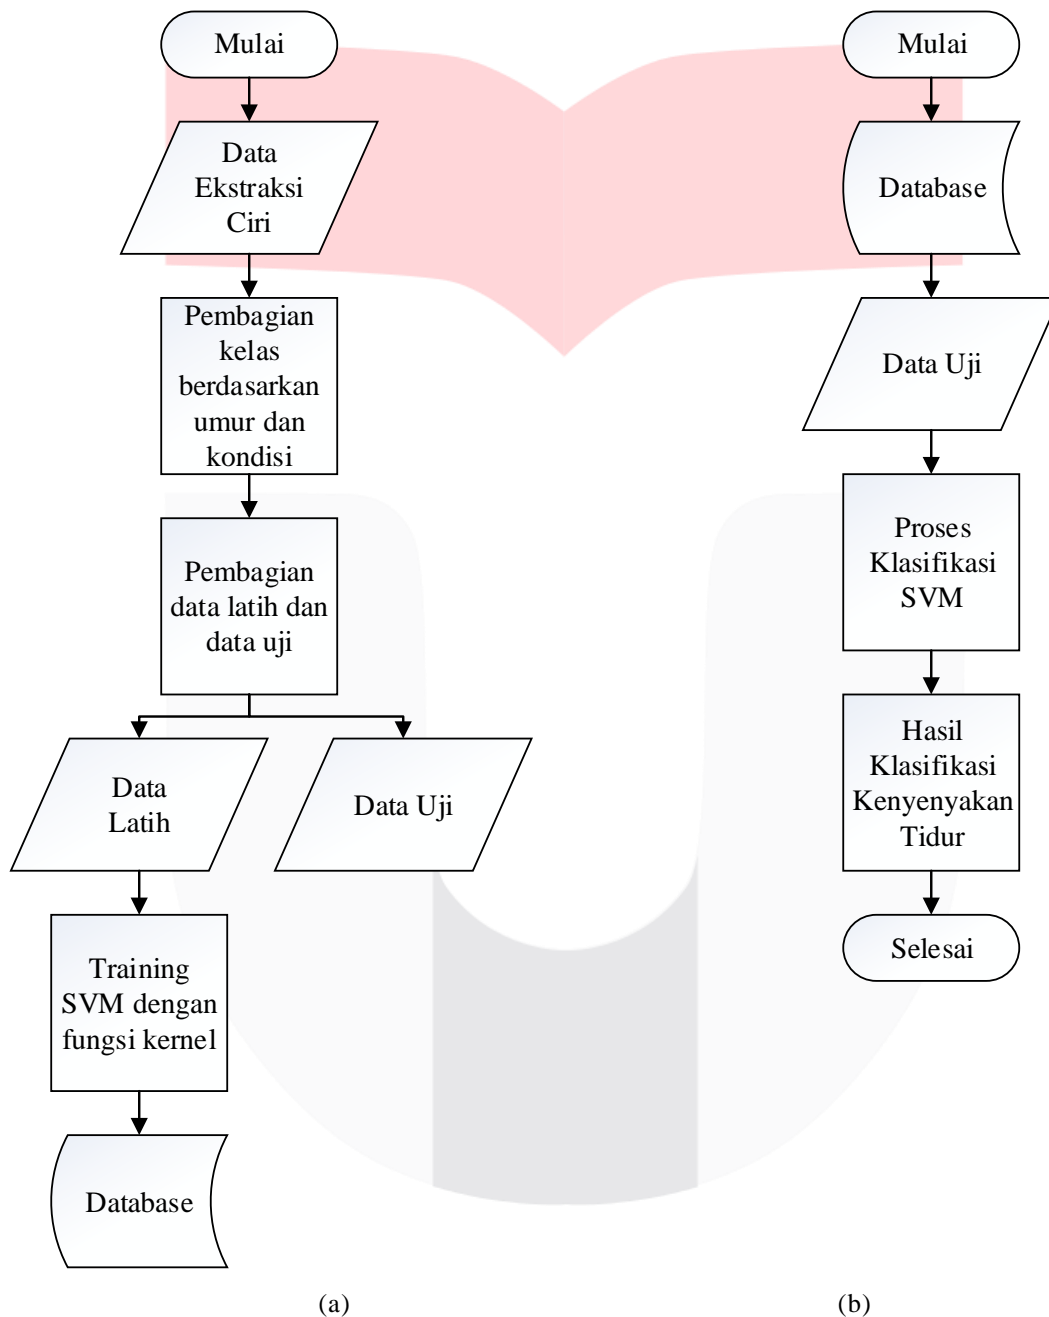
Parameter kompleksitas merepresentasikan perubahan pada frekuensi. Parameter ini membandingkan kemiripan sinyal dengan gelombang sinus murni.

$$\text{Kompleksitas} = \frac{\text{Mobilitas} \left(\frac{dy(t)}{dt} \right)}{\text{Mobilitas}(y(t))} \quad (2.3)$$

2.4 Support Vector Machine

Support Vector Machine adalah sebuah *linear classifier* dan akan dikembangkan menjadi *nonlinear classifier*. SVM ini pertamakali dibuat oleh Vapnik pada tahun 1995 [9], [10]. Tujuan utama SVM untuk mengubah *input* asli ke *feature dimension* yang lebih tinggi menggunakan fungsi kernel serta mencapai tingkat klasifikasi optimal di *feature space* yang baru[9].

Metode SVM memiliki kelebihan dimana menggunakan *Empirical Risk Minimization* (ERM) yaitu metode machine learning yang difokuskan pada usaha untuk meminimalkan error pada training-set, dan dalam SVM diwujudkan dengan memilih hyperplane dengan margin terbesar[9].



Gambar 2.1. (a) *Flowchart* proses pembentukan dan pelatihan data (b) *Flowchart* Blok proses pengujian dan klasifikasi SVM


3. Pembahasan

Berdasarkan pengelompokan data uji dan latih, data set langsung diklasifikasi dengan menggunakan fungsi kernel yaitu *Linear*, data input untuk dijadikan data latih dan data uji dikelompokkan berdasarkan kombinasi yang telah ditentukan pada Tabel 3.1

Tabel 3.1 Variabel kombinasi untuk pengujian sistem

| Variabel | Kombinasi Ciri |
|----------|---|
| U1 | Lampu Off pakai obat dengan Lampu Off biasa (20-30 tahun) |
| U2 | Mau Bangun pakai obat dengan Mau Bangun biasa (20-30 tahun) |
| U3 | Baru tidur pakai obat dengan Baru Tidur biasa (20-30 tahun) |
| U4 | Lampu Off pakai obat dengan Lampu Off biasa (30-40 tahun) |
| U5 | Mau Bangun pakai obat dengan Mau Bangun biasa (30-40 tahun) |
| U6 | Baru tidur pakai obat dengan Baru Tidur biasa (30-40 tahun) |
| U7 | Lampu off pakai obat (20-30 tahun) dengan Lampu off biasa (30-40 tahun) |
| U8 | Lampu off pakai obat (30-40) dengan Lampu off biasa (20-30) |
| U9 | Mau Bangun pakai obat (30-40 tahun) dengan Mau Bangun biasa (20-30 tahun) |
| U10 | Mau Bangun pakai obat (20-30 Tahun) dengan Mau Bangun biasa (30-40 tahun) |
| U11 | Baru tidur pakai obat (30-40 tahun) dengan Baru Tidur biasa (20-30 tahun) |
| U12 | Baru tidur pakai obat (20-30) dengan Baru Tidur biasa (30-40 tahun) |
| U13 | Lampu Off dengan Mau bangun |
| U14 | Lampu Off dengan Baru Tidur |
| U15 | Mau Bangun dengan Baru Tidur |

Tahap ini bertujuan untuk mengetahui apakah sistem dapat mengklasifikasi kenyamanan tidur berdasarkan umur dan juga melihat pengaruh sinyal delta saat lampu dimatikan kepada situasi yang lain. Dari hasil *tracing* data dalam percobaan kombinasi, di dapatkan hasil seperti Gambar 4.5.



Gambar 3.1 hasil akurasi berdasarkan kombinasi

Dari Gambar 3.1 Sistem dapat mengklasifikasi sesuai situasi yang terjadi jika sistem membandingkan data berbeda situasi, sistem tidak bisa dengan sempurna membaca data tersebut. Hal ini membuktikan bahwa sistem dapat mengklasifikasikan kenyamanan tidur berdasarkan umur dengan setiap situasi cuplikannya.

3.1 Analisis

Pada sinyal EEG terdapat suatu aspek yang disebut variansi normal dalam bentuk beberapa gelombang psikologis yang dimiliki tiap orang. Bentuk gelombang psikologis tiap orang yang bervariasi menyebabkan variansi normal dari sinyal EEG berbeda juga untuk tiap orangnya. Maka dari itu, dilakukan pengelompokan berdasarkan umur dan berdasarkan situasi beserta kondisi pakai obat atau tidak. Faktor lainnya juga bisa dijadikan alasan seperti tidak memungkinnnya menggeneralisir tingkat berapa lama nyenyak atau tidaknya tidur tiap orang karena tingkat berapa lama nyenyaknya tiap orang berbeda meskipun direkam pada waktu yang sama dan juga selesai pada waktu yang sama,

Pada hasil pengujian di skenario 1 ciri sinyal yang dipakai difokuskan pada setiap situasi dan untuk ekstraksi ciri data bisa dikatakan “Nyenyak” dikarenakan berdasarkan hasil survey yang ada pada penelitian Analysis of a Sleep-Dependent Neuronal Feedback Loop: The Slow-Wave Microcontinuity of the EEG.

Berdasarkan hasil pengujian, dapat ditarik kesimpulan bahwa dapat tercapai akurasi sistem sebesar 100% memakai fungsi kernel Linear pada setiap situasi berdasarkan umur dengan kondisi pakai obat dengan tidak pakai obat, karena saat sistem membaca data untuk situasi yang sama, sistem akan mengenali ciri terdekat yang sedang diujikan dalam database. Kemudian pada proses penelitian sistem dengan cara kombinasi ciri ternyata sistem tidak bisa sempurna untuk mendeteksi perbedaan situasi karena persamaannya sinyal antara Nyenyak dengan Kurang Nyenyak.

Pengujian paling bagus saat sistem pada situasi yang sama dan dalam rentang umur yang sama, dikarenakan pada setiap situasi yang sama namun beda umur tidak terlalu signifikan beda ciri sinyalnya tapi ada sedikit perbedaan di ciri sinyalnya sehingga sistem tidak mampu sempurna membaca data jikalau berbeda situasi maupun berbeda rentang umur.

4. Kesimpulan

Berdasarkan hasil skenario dan pengujian data yang dilakukan dapat ditarik kesimpulan, sebagai berikut :

1. Sistem mampu mengenali dan klasifikasi tiap situasi berdasarkan umur dengan hanya satu data yang tidak bisa diklasifikasikan dengan baik karena data tersebut *error*.
2. Percobaan terbaik terletak menggunakan fungsi kernel *linear* dengan akurasi maksimum 100% dan pada kombinasi mendapatkan akurasi minimum 70,15% karena ciri sinyal yang hampir sama (Mau bangun dengan Lampu off).
3. Dilihat dari kombinasi ciri dan akurasi penggunaan kernel *linear*, untuk saat ini sistem masih terbilang mampu dalam melakukan proses klasifikasi dengan baik dengan misklasifikasi 11 data dari keseluruhan 39 data

Daftar Pustaka:

- [1] R. Oliver and D. Suendermann, "A First Step towards Eye State Prediction Using EEG," *Proc. of the AIHLS*, 2013.
- [2] B. Kemp, A. H. Zwinderman, B. Tuk, H. A. C. Kamphuisen, and J. J. L. Oberyé, "Analysis of a sleep-dependent neuronal feedback loop: The slow-wave microcontinuity of the EEG," *IEEE Trans. Biomed. Eng.*, vol. 47, no. 9, pp. 1185–1194, 2000.
- [3] V. V. Vyazovskiy and A. Delogu, "NREM and REM sleep: Complementary roles in recovery after wakefulness," *Neuroscientist*, vol. 20, no. 3, pp. 203–219, 2014.
- [4] J. Carrier, S. Land, D. J. Buysse, D. J. Kupfer, and T. H. Monk, "The effects of age and gender on sleep EEG power spectral density in the middle years of life (ages 20-60 years old).," *Psychophysiology*, vol. 38, no. 2, pp. 232–242, 2001.
- [5] B. HJORTH, "THE PHYSICAL SIGNIFICANCE OF TIME DOMAIN DESCRIPTORS IN EEG ANALYSIS," pp. 321–325, 1973.
- [6] A. L. Goldberger *et al.*, "PhysioBank, PhysioToolkit, and PhysioNet : Components of a New Research Resource for Complex Physiologic Signals," *Circulation*, vol. 101, no. 23, pp. e215–e220, 2000.
- [7] A. Albajes-eizagirre and S. Dunne, "EEG / ERP Analysis : Methods and Applications," *Res. Gate*, no. October, pp. 1–10, 2014.
- [8] F. H. Lopes da Silva, S. I. Gonçalves, and J. C. De Munck, "Electroencephalography (EEG)," in *Encyclopedia of Neuroscience*, 2010, pp. 849–855.
- [9] G. Mehmet, "Multiple Kernel Learning Algorithms," vol. 12, pp. 2211–2268, 2011.
- [10] I. Wijayanto, A. Rizal, and S. Hadiyoso, "Multilevel Wavelet Packet Entropy and Support Vector Machine for Epileptic EEG Classification," in *4th International Conference on Science and Technology*, 2018.
- [11] N. T. K. Cuong, V. Q. Ha, N. T. M. Huong, T. Quang, and D. Khoa, "Removing Noise and Artifacts from EEG Using Adaptive Noise Cancelator and Blind Source Separation," pp. 282–286, 2010.